

Amerika Basketbol Ligi (NBA) Maç Sonuçlarının Yapay Sinir Ağları ile Tahmini

Ertuğrul AYYILDIZ

Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü - TRABZON

Özet

Bu çalışmada, Amerika Ulusal Basketbol Ligi (NBA) 2015-2016 sezonunun maç verilerinden yararlanılarak maç sonuçları yapay sinir ağları kullanılarak tahmin edilmeye çalışılmıştır. Bu tahmin maçı kimin kazanacağı bilgisini hedeflediği için 0 ya da 1 değeri alacağından sınıflandırma olarak tanımlanabilir. Çalışmada NBA 2015-2016 sezonunun farklı dilimlerinden seçilen 596 maç 11 farklı girdi parametresi ve 1 çıktı parametresi oluşacak şekilde modellenmiştir. Bu verilerden 396 tanesi eğitim kalan 200 tanesi ise test verisi olarak rastgele seçilerek her iki katmanında da 3 gizli nöron olan bir yapay sinir ağı tasarlanmıştır. Tasarlanan ağın transfer fonksiyonu olarak logaritmik sigmoid, çıktı fonksiyonu olarak ise purelin fonksiyonu kullanılmıştır, ayrıca ağın ürettiği değerler 0 ya da 1 e yuvarlanarak sınıflandırılması sağlanmıştır. Yaklaşık olarak yüzde 90 başarı yakalanan bu model özelinde yapay sinir ağları başarılı bir performans göstermiştir. Ayrıca hata matrisi incelenerek ağın hatalarının dengeli dağıldığı gösterilmiştir.

Anahtar Kelimeler: Yapay Sinir Ağları, NBA, Sınıflandırma, Hata Matrisi

Orijinal Makale

Yayın Bilgileri

Gönderi Tarihi: 01.02.2018

Kabul Tarihi: 20.02.2018

Yayın Tarihi: 25.03.2018

Sorumlu Yazar

e-mail: ertugrulayyildiz@ktu.edu.tr

Estimation of American Basketball League (NBA) Match Results by Artificial Neural Networks

Abstract

In this study, American National Basketball League (NBA) match results were tried to be predicted using artificial neural networks by using 2015-2016 season data. This prediction can be defined as a classification because it will take 0 to 1 value as the win or lose. In the study, 596 matches selected from different matchday of the NBA 2015-2016 season were modeled to have 11 different input parameters and 1 output parameter. 396 of them were trained and 200 of them were randomly selected as test data, and an artificial neural network with 3 hidden neurons was designed on both two layers. Logarithmic sigmoid was used as transfer function and purelin function was used as output function, and the values produced by the network are rounded to zero or one for clustering as win or lose. Artificial neural networks have performed well in this model, which is about 90% success. Moreover, by examining the confusion matrix, it has been shown that network faults are distributed regular.

Key Words: Artificial Neural Network, NBA, Clustering, Confusion Matrix

Original Article

Article Info

Received: 01.02.2018

Accepted: 20.02.2018

Published: 25.03.2018

Corresponding Author


e-mail: ertugrulayyildiz@ktu.edu.tr

Giriş

Canlıların vücudunun temel yapı taşı olan hücrenin önemli özelliklerinden biri de çevresinde yaşanan gelişmeleri göz önünde bulundurarak bu gelişmelerin hücreye olan etkisini göz önünde bulundurarak gerekli ayarlamaları yapabilmesi, yaptığı bu ayarlamaların hedefe ne derece uygun olduğunu ölçerek gerekli düzenlemeleri yapabilmesidir. Yani kısaca hücre “haberdar olma-karar verme-uygulama-düzeltilme” sistemini son derece gelişmiş bir şekilde kurabilmiş bir organizmadır. Sinir sisteminin de en önemli yapıtaşı bu sistemdir (Civalek, 1999).

Yapay Sinir Ağları bu işleyiş fikrinden doğarak, insan beyninin önemli özelliklerinden biri olan öğrenme yolu ile yeni bilgiler üretebilme, yeni bilgiler keşfedebilme gibi yetenekleri hiç bir yardım olmaksızın otomatik olarak gerçekleştirmek amacıyla tasarlanan bilgisayar sistemleridir (Öztemel, 2003). Yapay Sinir Ağları(YSA), biyolojik sinir sistemlerindeki benzer şekilde çalışan bir bilgi işletme sistemi olarak tanımlanabilir (Hamzaçebi, 2011). Haykin ise YSA'yı aşağıdaki gibi tanımlamaktadır:

Yapay Sinir Ağı; deneyime dayalı bilgiyi depolama ve bu bilgiyi kullanmaya yönelik doğal bir eğilim içinde olan yoğun paralel dağıtılmış bir işlemcidir. YSA iki açıdan insan beynine benzemektedir; Bilgi ağ tarafından bir öğrenme süreci vasıtasıyla elde edilmektedir ve sinir hücreleri arasında snaptik ağırlık olarak adlandırılan bağlar bilgiyi depolamakta kullanılmaktadır (Haykin, 1994) Bir yapay sinir ağının basitçe yapısı Şekil 1’de gösterilmiştir (Arslan ve İnce, 1996).



Şekil 1. Tek katmanlı YSA yapısı

Yapay sinir ağları, tıpkı insan zekası gibi örneklerle eğitilirler. Ağların eğitimde ne kadar çok örnek gösterilirse, problemi çözmeye başarısı o kadar yüksek olur (Arslan ve İnce, 1996). Ağın eğitilmesi belirli hata değerlerinin kabulü ile olur. Bir

ağda öğrenme ağırlık matrisinde değişme olarak düşünülebilir (Fırat ve Güngör, 2004).

Yapay Sinir Ağları, tahmin amacıyla girdi değerlerini alarak çıktı değerlerini tahmin etmek için kullanılır. Aynı şekilde sınıflandırma, veri ilişkilendirme, veri yorumlama, veri filtreleme gibi işlerde de yapay sinir ağları kullanılabilir (Akkaya ve ark., 2009).

Yapay Sinir Ağları Kullanım Alanları

Çok geniş bir kullanım alanına sahip olan yapay sinir ağları kullanıldığı bazı alanlar aşağıda listelenmiştir (Yazıcı ve ark., 2006).

- Otomotiv sektöründe (Karaatlı ve ark. 2012),
- Bankacılıkta (Çelik, 2010),
- Uzay sanayisinde (Hsu ve ark., 1995),
- Elektrik alanında (Park ve ark., 1991),
- Finans alanında (Ahn ve ark., 2000),
- Sağlık alanında (Floyd ve ark., 1994),
- Askeri alanda (Wong ve Nandi, 2004),
- Endüstri alanında (Meireles ve ark., 2003),
- Ürünlerin tasarımında (Zhou ve ark., 2009),
- Ürünlerin kalite kontrolünde (Karayel, 2009)
- Çevre kirliliği (Rehman ve Mohandes, 2008),
- Sigortacılık (Zhang ve ark., 2009),
- Eğlence (Silver ve ark., 2006),
- Petrokimya (Mohaghegh ve ark., 2006),
- Robotik uygulamaları (Pomerleau ve ark., 1991),
- Spor (Studenmayer ve ark.,, 2009), vb.

Yapılan bu çalışmada ise yapay sinir ağları kullanılarak Amerika Ulusal Basketbol Ligi (NBA) 2015-2016 sezonunun maç verilerinden yararlanılarak maç sonuçları tahmin edilmeye çalışılmıştır. Kurulan modelde 11 farklı girdi parametresi kullanılmış, tek çıktı olan maç sonucu tahmin edilmiştir.

Dünyada futboldan sonra en çok izlenen spor olan Basketbol, 19. Yüzyılda ilk olarak oynanmaya başlandığı Amerika Birleşik Devletleri'nde ise izlenme oranı olarak

ilk sırada gelmektedir. NBA ise Amerika Birleşik Devletleri'nde kurulmuş ulusal basketbol ligi organizasyonudur. Ülkemiz de dahil olmak üzere nerdeyse tüm dünyada yayınlanan NBA maçları genç yaşlı herkesin ilgisini çekmekte ve tüm dünyada milyonlarca insanı aynı anda ekrana kilitlemektedir. Oyunun izlenmesini ve sürekli göz önünde bulunmasını sağlayan başlıca etmenler ise birçok ülkeden daha büyük bütçelere sahip NBA takımlarının aralarındaki tarihi rekabetler, maçlarındaki çekişmeler ve anlık şovların son derece ilgi çekici olmasıdır. Bu maçlardaki çekişmeler ise maç sonucunu tahmin etmeyi zor kılmakla birlikte taraftar için heyecanı arttırmaktadır. NBA özelinden genele geçilecek olursa, insan faktörünün önemli bir rol oynadığı spor müsabakalarında tahmin yapmak oldukça zordur. Michael Pardee (1999) çalışmasında Kolej Ligi'nde futbol müsabakalarını tahmin etmeyi amaçlamış ve bunun için 12 gizli nörondan oluşan bir YSA modeli hazırlamıştır. Yaklaşık 200 adet olan örnek sayısının yarısını test, yarısını eğitim olarak böldüğü modelinde %50 bir başarı yakalamıştır. Wilson ise (1995) Kolej Futbol takımlarını YSA modeliyle sıralamaya çalışmış fakat çok başarılı sonuçlar elde edememiştir. Feifang ve ark., (2004) ağırlıklı tahmin metotlarını kullanarak NBA maçlarını tahmin etmiş ve %67 başarı yakalamıştır. Her 3 maçın 2'sinin kazananı doğru tahmin eden modelinde tamamen matematiksel formüllerden yararlanmıştır. Radojicic (2008) ise futbol müsabakalarını tahmin etmeye yönelik bir çalışma yayınlamış ve bu çalışmasında kaleci, defans, ortasaha, forvet puanlarını kullanarak maç sonucunu tahmin etmek istemiştir, 3 sonuçlu (galibiyet, beraberlik ve mağlubiyet) bir müsabaka olan futbolda %83 başarı yakalamıştır.

Kurulan Modelde Kullanılan Veriler

Yapılan gözlem ve araştırmaların ardından karar verilen model parametreleri aşağıdaki gibidir.

Ev Sahibi Takım-Deplasman Takım

Maçın sonucunun tahmin edilebilmesi için ilk olarak maçı oynayacak takımların bilgisi gerekmektedir. Bu amaçla her Amerika Ulusal Basketbol Ligi takımına alfabetik sıraya uygun olarak 1 ile 30 arasında değer atanmıştır. Takımların listeleri ve matematiksel değerleri Tablo 1'de gösterilmektedir.

Tablo 1. Ligde Yer Alan Takımlar

Değer	Takım Adı	Değer	Takım Adı
1	Atlanta Hawks	16	Miami Heat
2	Boston Celtics	17	Milwaukee Bucks
3	Brooklyn Nets	18	Minnesota Timberwolves
4	Charlotte Hornets	19	New Orleans Pelicans
5	Chicago Bulls	20	New York Knicks
6	Cleveland Cavaliers	21	Oklahoma City Thunder
7	Dallas Mavericks	22	Orlando Magic
8	Denver Nuggets	23	Philadelphia 76ers
9	Detroit Pistons	24	Phoenix Suns
10	Golden State Warriors	25	Portland Trail Blazers
11	Houston Rockets	26	Sacramento Kings
12	Indiana Pacers	27	San Antonio Spurs
13	Los Angeles Clippers	28	Toronto Raptors
14	Los Angeles Lakers	29	Utah Jazz
15	Memphis Grizzlies	30	Washington Wizards

Güncel Sezon Galibiyet Yüzdeleri

Maçta oynayacak takım bilgisi girildikten sonra, bu iki takımın o sezonki performansı, takım kadrosu arasındaki kıyaslamaların en sağlıklı biçimde olması için her iki takımın maçın başlama düdüğünden önceki galibiyet yüzdeleri girilmiştir. Bu galibiyet yüzdeleri veri setinin ilk satırlarında 1(%100), 0(%0) gibi değerler alırken veri setinin ilerleyen kısımlarında birbirlerine daha yakın olduğu gözlemlenmiştir. Bu da hiç bir takımın, bir diğerine mükemmel derecede üstünlük kuramayacağını göstermesi açısından önemlidir. Ayrıca her maç öncesi güncellendiği için değerler bir takımın sezon başındaki sütun değeri sezon içerisinde sürekli değişim göstermektedir. Bu da veri setine dinamik bir hal kazandırarak, veri setinde aynı verilerin tekrarının önüne geçmektedir. Tablo 2’de örnek olarak takım matematiksel değeri 1 olan Atlanta Hawks’ın güncel sezon yüzdeleri gösterilmiştir. Tablodan takım yüzdesinin sezon farklı kısımlarında nasıl değişkenlik gösterdiği kolayca anlaşılabilir.

Tablo 2. Atlanta Hawks takımının sezon içerisinde farklı zaman dilimlerindeki galibiyet yüzdeleri

Sezon Başı	Sezon Ortası	Sezon Sonu
0.83	0.59	0.59
0.88	0.56	0.58
0.78	0.55	0.59
0.80	0.54	0.58
0.77	0.53	0.59
0.78	0.54	0.60

Son 3 Maç Galibiyet Yüzdesi

Takımların güncel sezon galibiyet yüzdelerini girdi olarak belirledikten sonra, güncel form durumlarının da modelde girdi olarak kullanılmasına karar verildi. Bu amaçla takımların son maç, son 3 maç, son 5 maç olmak üzere üç farklı güncel form durumunu belirleyen faktör belirlendi. Yapılan analizlerin ardından bu 3 değişkenden oynanacak maça etkisi en büyük olan etkenin son 3 maç olduğu belirlendi. 0, 0.33, 0.66, 1 olmak üzere 4 farklı değer alabilen bu değişken, yapay sinir ağlarında kullanılan veri setine girdi olarak, her iki takım için de (Ev Sahibi Son 3 Maç-Deplasman Son 3 Maç olarak) tanımlandı.

Ev Sahibi Takımın İç Saha, Deplasman Takımının Dış Saha Yüzdesi

Amerika Ulusal Basketbol Ligi'nde her maç neredeyse dolu salon önünde oynandığı için taraftar ev sahibi takım için önemli bir katkı olarak düşünülebilir. Takıma moral vermede önemli bir etken olan taraftarın da maç sonucunda olan etkisini göstermek için ev sahibi takımın kendi sahasındaki maç kazanma yüzdesi modele girdi olarak tanımlanmıştır. Aynı şekilde evinden uzakta oynamakta olan deplasman takımının da rakip taraftar önünde zorlanacağı düşünülerek veri setine deplasman takımının dış sahada kazanma yüzdesi de eklenmiştir.

Geçmiş Sezon Galibiyet Yüzdeleri

Belirlenen tüm girdi parametrelerinin dinamik bir şekilde değişken olmasından yanında modelde bir de sabit değişken tanımlayarak, daha doğru tahminlerin üretilmesi düşünülmüştür. Bu bağlamda yapılan çalışmalar sonucunda bir önceki sezon galibiyet yüzdesinin de takımların kıyaslanmasında kullanılabileceği

anlaşılmıştır ve bir önceki sezon (2014) galibiyet yüzdeleri modele girdi olarak tanımlanmıştır.

Handikap

Tasarlanan modelde zaman kısıdından dolayı maç sonucunu etkileyen günlük haftalık faktörler göz ardı edilmiştir. Bunlardan başlıcaları sakatlık, koç değişikliği, transferler olarak düşünülebilir. Modele bu faktörleri eklemek amacıyla bahis sitelerinin analizler sonucunda iki takım arasındaki güç farkını ortaya koyan, kavramsal olarak güçsüz takımın maça önde başlaması anlamına gelen değerler vardır. Bunu açmak gerekirse 10 handikap verilen deplasman takımı maça 10-0 önde başlıyor gibi düşünülebilir. Yani iki takım arasındaki o günkü güç farkı 10 sayılı bir fark olarak tanımlanmıştır. Modelde kullanılan handikaplar dünyanın en büyük bahis sitelerinden birinden alınmıştır.

Maç Sonucu

Yapılan yapay sinir ağı modelinde çıktı olarak maç sonucunun alınmasına karar verilmiştir. Yani maçı kimin kazandığı çıktı parametresi olarak belirlenmiştir. Eğer ev sahibi takım maçı kazanmışsa 0, deplasman takımı kazanmışsa 1 olarak modele girilmiştir. Alternatif olarak aradaki farkı çıktı olarak düşünmek ise yapay sinir ağı modelin başarısını düşürdüğü için kullanılmamıştır.

Kullanılan Yapay Sinir Ağları Modeli

Daha önce bahsedilen veriler Amerikan Ulusal Basketbol Ligi'nin resmi internet sitesinden her maç için ayrı ayrı alınarak 596 adet örnek elde edilmiştir. Bu 596 örnekten oluşan veri seti aşağıdaki 11 girdi parametresi ve 1 çıktı parametresinden oluşmaktadır;

Kullanılan Parametreler:

- Ev Sahibi Takım
- Deplasman Takımı
- Ev Sahibi Takım Güncel Kazanma Yüzdesi
- Ev Sahibi Takım Son 3 Maç Kazanma Yüzdesi
- Ev Sahibi Takım Kendi Evinde Kazanma Yüzdesi
- Ev Sahibi Takım 2014 Yılı Kazanma Yüzdesi

- Deplasman Takımı Güncel Kazanma Yüzdesi
- Deplasman Takımı Son 3 Maç Kazanma Yüzdesi
- Deplasman Takımı Kendi Evinde Kazanma Yüzdesi
- Deplasman Takımı 2014 Yılı Kazanma Yüzdesi
- Handikap
- Maç Sonucu (Çıktı)

Bu veriler Matlab r2013a programı vasıtasıyla kodlanarak çeşitli katman sayıları ve gizli nöron kombinasyonları denenmiştir. Programda kullanılan kod ekler kısmında verilmiştir. 596 adet verinin 396 tanesi eğitim kümesi kalan 200 tanesi ise test kümesine dahil edilmiştir. Sonuçlar değerlendirirken ise ağın ürettiği çıktılar 0 ya da 1e yuvarlanarak karar verilmiştir. Bu yüzden performans parametresi olarak MAPE (Mean Absolute Percentage Error) yerine ağın ürettiği sonucun yuvarlanarak elde edilen tahminin gerçek sonuçla kıyaslanmasıyla elde edilen yanlış sayısının olmasına karar verilmiştir. İlk deneme setinde 2 katman olarak tasarlanan ağın ilk katmanında 4 ve 5, ikinci katmanında ise 5,6,7 ve 8 olacak şekilde kod oluşturulmuştur. Yazılan kod bu değerlerin ikili kombinasyonlarının her birini ayrı ayrı sinir ağları oluşturarak çalışmasını sağlar. Bu koşturmadan elde edilen sonuçlar Tablo 3'te gösterilmiştir.

Tablo 3. İlk koşturma sonuçları

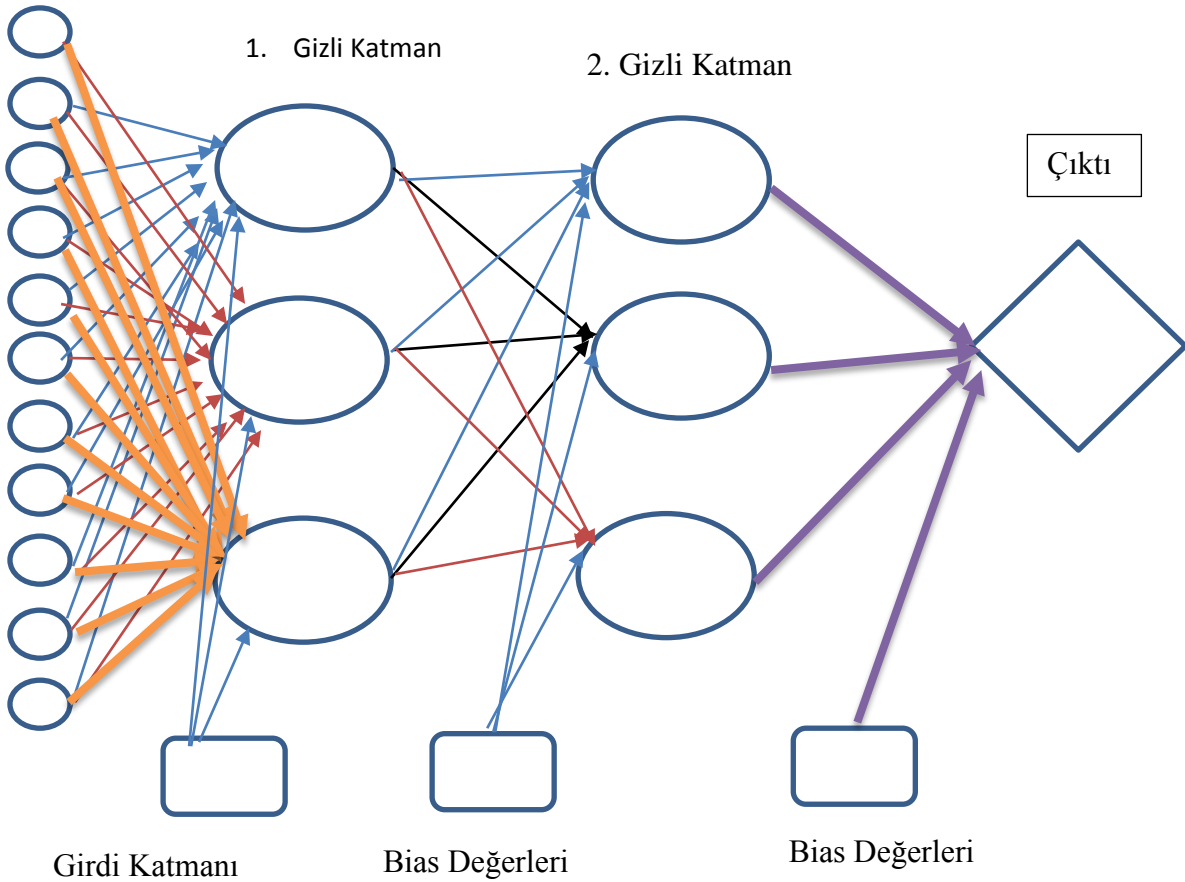
Gizli Nöron1	Gizli Nöron2	Epoch Numarası	Eğitim Hatası	Test Hatası
4	6	148	18	23
4	8	157	21	27
4	5	176	20	24
4	7	105	20	24
5	5	221	9	29
5	6	299	13	29
5	7	265	9	29
5	8	143	9	31

Tablo 3'ten de görülebileceği üzere nöron sayısı azaldıkça, yapay sinir ağları daha iyi sonuçlar vermiştir. Bu değerler göz önüne alınarak; kodun ilk katmanın 3,4 ikinci katmanının 3,4,5 olacak (tüm ikili kombinasyonlar olacak şekilde) şekilde oluşturulmuştur. Bu koşturmadan elde edilen sonuçlar ise Tablo 4'te gösterilmiştir.

Tablo 4. İkinci koşturma sonuçları

Gizli Nöron1	Gizli Nöron2	Epoch Numarası	Eğitim Hatası	Test Hatası
3	3	184	22	21
3	5	149	21	21
3	4	172	31	23
4	3	213	28	23
4	4	264	15	23
3	4	212	14	25

Tablo 4'te de görüldüğü gibi en iyi performansı veren ağ yapısı ilk katmanda 3 gizli nöron, ikinci katmanda 3 gizli nörondan oluşan ağ yapısıdır. Bu ağ yapısında eğitim fonksiyonu olarak **TRAINLM** (Levenberg-Marquardt backpropagation), transfer fonksiyonu olarak logaritmik sigmoid çıktı fonksiyonu olarak **purelin** fonksiyonu kullanılmıştır. Bu fonksiyonlar kullanılarak oluşturulan ağ modeli Şekil 2'de gösterilmiştir.

**Şekil 2.** Modelde Kullanılan Yapay Sinir Ağı Yapısı

Bulgular

Veri seti için oluşturulan modelde 596 veri kullanılmıştır. Bunların içersinden, 396 adet (yaklaşık %67) veri eğitim, 200 adet veri ise test için rastgele olacak şekilde seçilmiştir. Daha öncede anlatıldığı üzere nöron sayıları değiştirilerek modelde başarı arttırılmaya çalışılmıştır. En yüksek doğruluk payına sahip iki katmanlı her bir katmanda 3er gizli nörondan oluşan modelin çıktılarının bir kısmı (test kümesinde ilk 100 örnek için) Tablo 5'te verilmiştir. Tablodan da görüleceği üzere yuvarlama yapmak tahmin için daha gerçekçi bir sonuç oluşturmakla beraber, maçın oynandığı andaki planlanamayan etkiler yüzünden bazı tahminlerinde ağ büyük hatalar yapmıştır fakat genel olarak test kümesinde bulunan 200 adet karşılaşmadan 179 tanesine doğru sonuç vererek yaklaşık olarak yüzde 90'lık bir başarı yakalamıştır. Yapay sinir ağları modellerinde genel olarak başarılı ağ diye nitelendirilen yüzde 10'luk hata dilimine, oldukça fazla değişkene ve insan faktörüne sahip bir spor dalında girebilmesi açısından ağın performansı küçümsenemeyecek kadar iyidir.

Tablo 5. Ağın ürettiği sonuçların gerçek değerlerle değerlendirilmesi

Ağ Çıktısı	Çıktı	Sonuç	Ağ Çıktısı	Çıktı	Sonuç	Ağ Çıktısı	Çıktı	Sonuç	Ağ Çıktısı	Çıktı	Sonuç
0.23	0	0	0.06	0.00	0.00	0.09	0	0	0.03	0	0
0.95	1	1	1.13	1.00	1.00	0.44	0	0	1.19	1	1
0.02	0	0	-0.02	0.00	0.00	0.25	0	1	1.13	1	1
0.95	1	1	0.94	1.00	1.00	0.60	1	1	-0.01	0	0
0.51	1	1	0.04	0.00	0.00	0.04	0	0	0.95	1	1
0.95	1	1	0.95	1.00	1.00	0.05	0	0	0.02	0	0
0.36	0	0	-0.02	0.00	0.00	0.95	1	1	0.04	0	0
-0.39	0	1	0.04	0.00	0.00	0.94	1	1	0.04	0	0
0.49	0	0	0.47	0.00	0.00	0.95	1	0	0.48	0	0
0.06	0	0	0.93	1.00	1.00	0.02	0	0	0.84	1	0
0.06	0	0	0.03	0.00	0.00	0.95	1	1	0.07	0	0
0.15	0	0	0.01	0.00	0.00	0.85	1	1	0.03	0	0
0.08	0	0	0.51	1.00	0.00	0.61	1	1	1.19	1	0
0.95	1	1	0.04	0.00	0.00	0.80	1	1	0.05	0	0
0.95	1	1	-0.34	0.00	0.00	0.04	0	0	-0.02	0	0
0.95	1	1	0.10	0.00	0.00	0.86	1	1	-0.02	0	0
0.63	1	1	0.95	1.00	1.00	0.95	1	1	0.05	0	0
1.17	1	1	0.73	1.00	1.00	0.30	0	0	0.95	1	1

0.14	0	0	0.17	0.00	0.00	0.52	1	1	0.04	0	0
0.20	0	0	0.95	1.00	1.00	0.04	0	0	0.77	1	1
0.87	1	1	-0.05	0.00	0.00	0.08	0	0	0.18	0	0
0.04	0	0	1.19	1.00	1.00	0.04	0	0	0.04	0	0
0.02	0	0	0.45	0.00	0.00	0.95	1	0	1.10	1	1
1.00	1	1	-0.02	0.00	0.00	1.09	1	1	1.13	1	1
-0.35	0	0	0.06	0.00	0.00	0.04	0	0	1.10	1	1

Sonuçlar

Ağın oluşturduğu değerleri gerçek değerlerle kıyasladıktan sonra confusion matriks oluşturularak ağın yansız hatalar ürettiği gösterilmeye çalışılmıştır. 200 veriden oluşan test kümesinin hata matrisi aşağıdaki Şekil 3'te yer almaktadır.

		Tahmin	
		0	1
gerçek	0	104	9
	1	12	75

Şekil 3. Hata Matrisi

Matrise göre yapay sinir ağının performans değerleri aşağıdaki gibidir.

$$\text{Doğruluk (Accuracy)} = \frac{\text{Doğru pozitif} + \text{Doğru Negatif}}{\text{Toplam Eleman}} = \frac{104 + 75}{200} = \%89.5$$

$$\text{PPV (Positive Prediction Value)} = \frac{\text{Doğru pozitif}}{\text{Test sonucu pozitif}} = \frac{75}{84} = \%89$$

$$\text{FDR (False Discovery Rate)} = \frac{\text{Yanlış pozitif}}{\text{Test sonucu pozitif}} = \frac{9}{84} = \%11$$

$$\text{FOR (False Omission Rate)} = \frac{\text{Yanlış negatif}}{\text{Test sonucu negatif}} = \frac{12}{116} = \%10$$

$$\text{NPV (Negative Prediction Value)} = \frac{\text{Doğru negatif}}{\text{Test sonucu negatif}} = \frac{104}{116} = \%90$$

Yukarıdaki değerlerden görüldüğü üzere kurulan ağ yanlı hatalar üretmemiş, hata eşit olarak dağılmıştır. Bu da modelde mantıksal bir hata olmadığını göstermesi açısından önemlidir.

Sonuç olarak 596 adet veriden oluşan veri seti 396 eğitim, 200 test olmak üzere ikiye ayrılarak, değişik nöron sayıları ile iki katmanlı yapay sinir ağları için denemeler yapılarak, en iyi çözümünün 3er gizli nöronlu 2 katmanlı ağ yapısı olduğu anlaşılmıştır. Bu ağ yapısında yakalanan yaklaşık olarak %90lık başarı oranı daha önce yapılan çalışmalar incelendiğinde başarılı bir ağ yapısı olduğunu gözler önüne sermektedir. Bir spor müsabakasının tahmini yapılırken insan faktörü de önemli rol oynadığından bazen ağın çok büyük hatalar yapması son derece normaldir, fakat yuvarlanan değerlerden 0a yakın olanlar da ev sahibi takımın daha baskın, 1e yakın olanlarda ise deplasman takımının daha baskın bir galibiyet aldığı test kümesinin sonuçları ile gerçek maç sonuçları karşılaştırıldığında açıkça gözükmektedir.

Kaynaklar

- Ahn, B. S., Cho, S. S., & Kim, C. Y. (2000). The integrated methodology of rough set theory and artificial neural network for business failure prediction. *Expert systems with applications*, 18(2): 65-74.
- Akkaya, G. C., Demireli, E., & Yakut, Ü. H. (2009). İşletmelerde finansal başarısızlık tahminlemesi: Yapay sinir ağları modeli ile İMKB üzerine bir uygulama. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 10(2): 187-216.
- Arslan, A., & Ince, R. (1996). The neural network approximation to the size effect in fracture of cementitious materials. *Engineering Fracture Mechanics*, 54(2): 249-261.
- Civalek, Ö., (1999) Dairesel Plakların Nöro-Fuzzy Tekniği ile Analizi, DEÜ Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 1(2): 13-31.
- Çelik, M. K. (2010). Bankaların Finansal Başarısızlıklarının Geleneksel ve Yeni Yöntemlerle Öngörüsü. *Yönetim ve Ekonomi: Celal Bayar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 17(2): 129-143.
- Firat, M., & Güngör, M. (2004). Askı madde konsantrasyonu ve miktarının yapay sinir ağları ile belirlenmesi. *Teknik Dergi*, 15(73): 3267-3283.
- Floyd, C. E., Lo, J. Y., Yun, A. J., Sullivan, D. C., & Kornguth, P. J. (1994). Prediction of breast cancer malignancy using an artificial neural network. *Cancer*, 74(11): 2944-2948.
- Hamzaçebi, C. (2011). Yapay sinir ağları: tahmin amaçlı kullanımı MATLAB ve Neurosolutions uygulamalı. Ekin Basım Yayın Dağıtım, Bursa.

- Haykin, S. (1994). *Neural networks: A comprehensive foundation*: Macmillan college publishing company. New York.
- Hsu, K. L., Gupta, H. V., & Sorooshian, S. (1995). Artificial neural network modeling of the rainfall-runoff process. *Water resources research*, 31(10): 2517-2530.
- Hu, F., & Zidek, J. V. (2004). Forecasting NBA basketball playoff outcomes using the weighted likelihood. *Lecture Notes-Monograph Series*, 385-395.
- Karaatli, M., Helvacioğlu, Ö. C., Ömürbek, N., & Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17): 87-100.
- Karayel, D. (2009). Prediction and control of surface roughness in CNC lathe using artificial neural network. *Journal of materials processing technology*, 209(7): 3125-3137.
- Meireles, M. R., Almeida, P. E., & Simões, M. G. (2003). A comprehensive review for industrial applicability of artificial neural networks. *IEEE transactions on industrial electronics*, 50(3): 585-601.
- Mohaghegh, S., Arefi, R., Ameri, S., Aminand, K., & Nutter, R. (1996). Petroleum reservoir characterization with the aid of artificial neural networks. *Journal of Petroleum Science and Engineering*, 16(4): 263-274.
- Öztemel, E. (2003). *Yapay Sinir Ağları*. PapatyaYayincilik, İstanbul.
- Pardee, M. (1999). An artificial neural network approach to college football prediction and ranking. University of Wisconsin–Electrical and Computer Engineering Department.
- Park, D. C., El-Sharkawi, M. A., Marks, R. J., Atlas, L. E., & Damborg, M. J. (1991). Electric load forecasting using an artificial neural network. *IEEE transactions on Power Systems*, 6(2): 442-449.
- Pomerleau, D. A. (1991). Efficient training of artificial neural networks for autonomous navigation. *Neural Computation*, 3(1): 88-97.
- Radovanović, S., Radojčić, M., & Savić, G. (2014). Two-phased DEA-MLA approach for predicting efficiency of NBA players. *Yugoslav Journal of Operations Research*, 24(3): 347-358.
- Rehman, S., & Mohandes, M. (2008). Artificial neural network estimation of global solar radiation using air temperature and relative humidity. *Energy Policy*, 36(2), 571-576.

- Staudenmayer, J., Pober, D., Crouter, S., Bassett, D., & Freedson, P. (2009). An artificial neural network to estimate physical activity energy expenditure and identify physical activity type from an accelerometer. *Journal of Applied Physiology*, 107(4):1300-1307.
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., & Dieleman, S. (2016). Mastering the game of Go with deep neural networks and tree search. *nature*, 529 (7587): 484-489.
- Wilson, R. L. (1995). Ranking college football teams: A neural network approach. *Interfaces*, 25(4): 44-59.
- Wong, M. D., & Nandi, A. K. (2004). Automatic digital modulation recognition using artificial neural network and genetic algorithm. *Signal Processing*, 84(2): 351-365.
- Yazici, A. C., Ögüş, E., Ankarali, S., Canan, S., Ankarali, H., & Akkuş, Z. (2007). Yapay Sinir Ağlarına Genel Bakış. *Türkiye Klinikleri Journal of Medical Sciences*, 27(1): 65-71.
- Zhang, G., Hu, M. Y., Patuwo, B. E., & Indro, D. C. (1999). Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis. *European journal of operational research*, 116(1): 16-32.
- Zhou, C. C., Yin, G. F., & Hu, X. B. (2009). Multi-objective optimization of material selection for sustainable products: artificial neural networks and genetic algorithm approach. *Materials & Design*, 30(4): 1209-1215.